

Programación de GPUs con CUDA

Alvaro Cuno

23/01/2010

Agenda

- GPUs
- Cuda
- Cuda + OpenGL

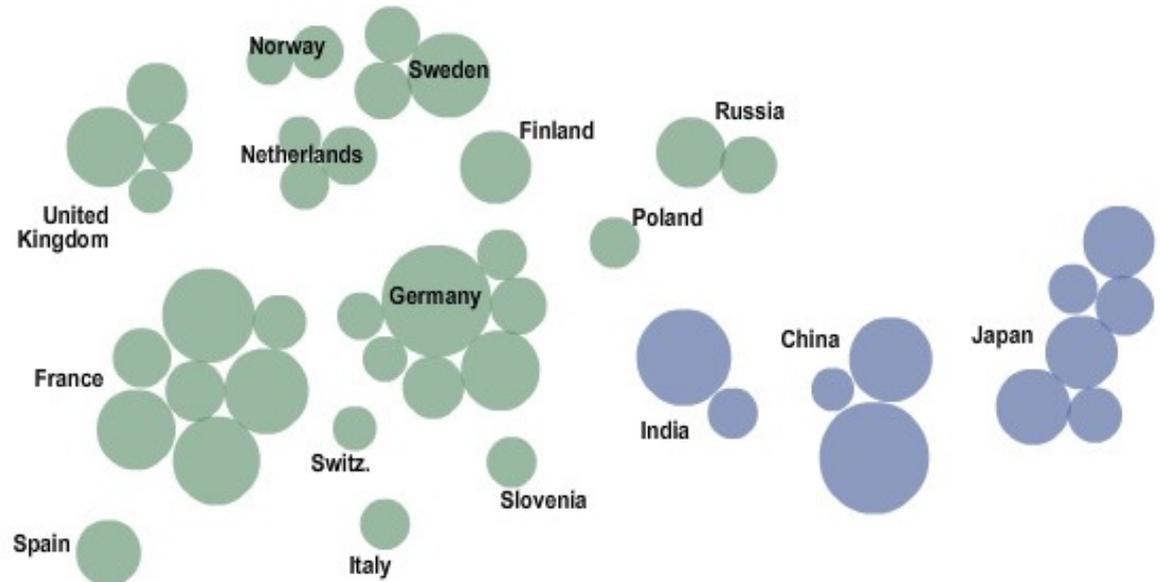
GPUs

(Graphics Processing Units)

Supercomputadores

Mapa de los 100 supercomputadores

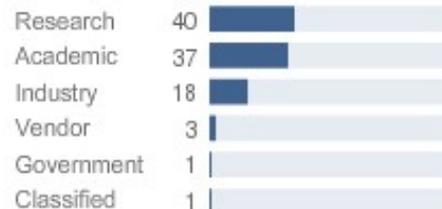
[1700 teraflops – 27 teraflops] [US\$133M -]



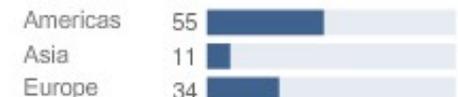
Circles are sized according to their maximum processing speed in teraflops. A teraflop is about equal to the processing power of 1,000 personal computers.

A breakdown of the 100 fastest supercomputers in 2008

AREA OF USE



CONTINENT



Sudamérica: posiciones 306 y 363 (Brasil).

Fuente <http://www.top500.org/>

Arquitecturas paralelas

- Sistemas con memoria distribuida o compartida
- Clusters
 - Cientos de KiloWatts de consumo
 - Alto costo de instalación y mantenimiento
- Comparado con arquitecturas secuenciales
 - Pocos usuarios (grandes instituciones)
 - Pocas herramientas para desarrollo

Alternativas modernas

- Arquitecturas multi-core/many-core
 - Actualmente 4 cores
 - 128 cores en 12 años
- Arquitectura Cell (Playstation 3)
- Xbox 360 (Microsoft)
- **Placas gráficas (GPUs)**

Computadores con GPUs

- Tesla Computing System
 - 4 GPUs 240 cores c/u
 - 4 TeraFlops SP
 - Precio: US\$ 10 000
- Desktop/GPU
 - 1 GPU, 128 cores
 - 470 GigaFlops
 - Precio: US\$ 300

Computadores con GPUs

- Tesla Computing System
 - 4 GPUs 240 cores c/u
 - 4 TeraFlops SP
 - Precio: US\$ 10 000
- Desktop/GPU
 - 1 GPU, 128 cores
 - 470 GigaFlops
 - Precio: US\$ 300

**Procesamiento
paralelo
para las masas!!!**

- The 29th most powerful supercomputer is GPU-based technology (170 teraflops)

GPUs

- Evolución producto del insaciable mercado de gráficos 3D de alta calidad (juegos, industria del cine, etc.)

GPUs

- Evolución producto del insaciable mercado de gráficos 3D de alta calidad (**juegos**, industria del cine, etc.)



2009

GPUs

- Evolución producto del insaciable mercado de gráficos 3D de alta calidad (**juegos**, industria del cine, etc.)



GPUs

- Evolución producto del insaciable mercado de gráficos 3D de alta calidad (juegos, **industria del cine**, etc.)

GPUs

- Evolución producto del insaciable mercado de gráficos 3D de alta calidad (juegos, **industria del cine**, etc.)



2D animation



GPUs

- Evolución producto del insaciable mercado de gráficos 3D de alta calidad (juegos, industria del cine, etc.)
 - Placas gráficas de funcionalidad fija
 - GPUs programables
 - Altamente paralelas
 - Multicores (soporte a múltiples hilos)
 - Altísimo poder de calculo
 - Gran ancho de banda: GPU y su memoria

GPU

- Es un procesador extremamente potente, flexible y de bajo costo



Placa de video Nvidia GeForce 8800GT

GPU

- Es un procesador extremamente potente, flexible y de bajo costo
- Originalmente diseñado para procesamiento gráfico en 3D
 - Rendering of polygons
 - Texturing
 - Shading



Placa de video Nvidia GeForce 8800GT

GPU: poder de cómputo

Intel Core2 Quad 3.0GHz

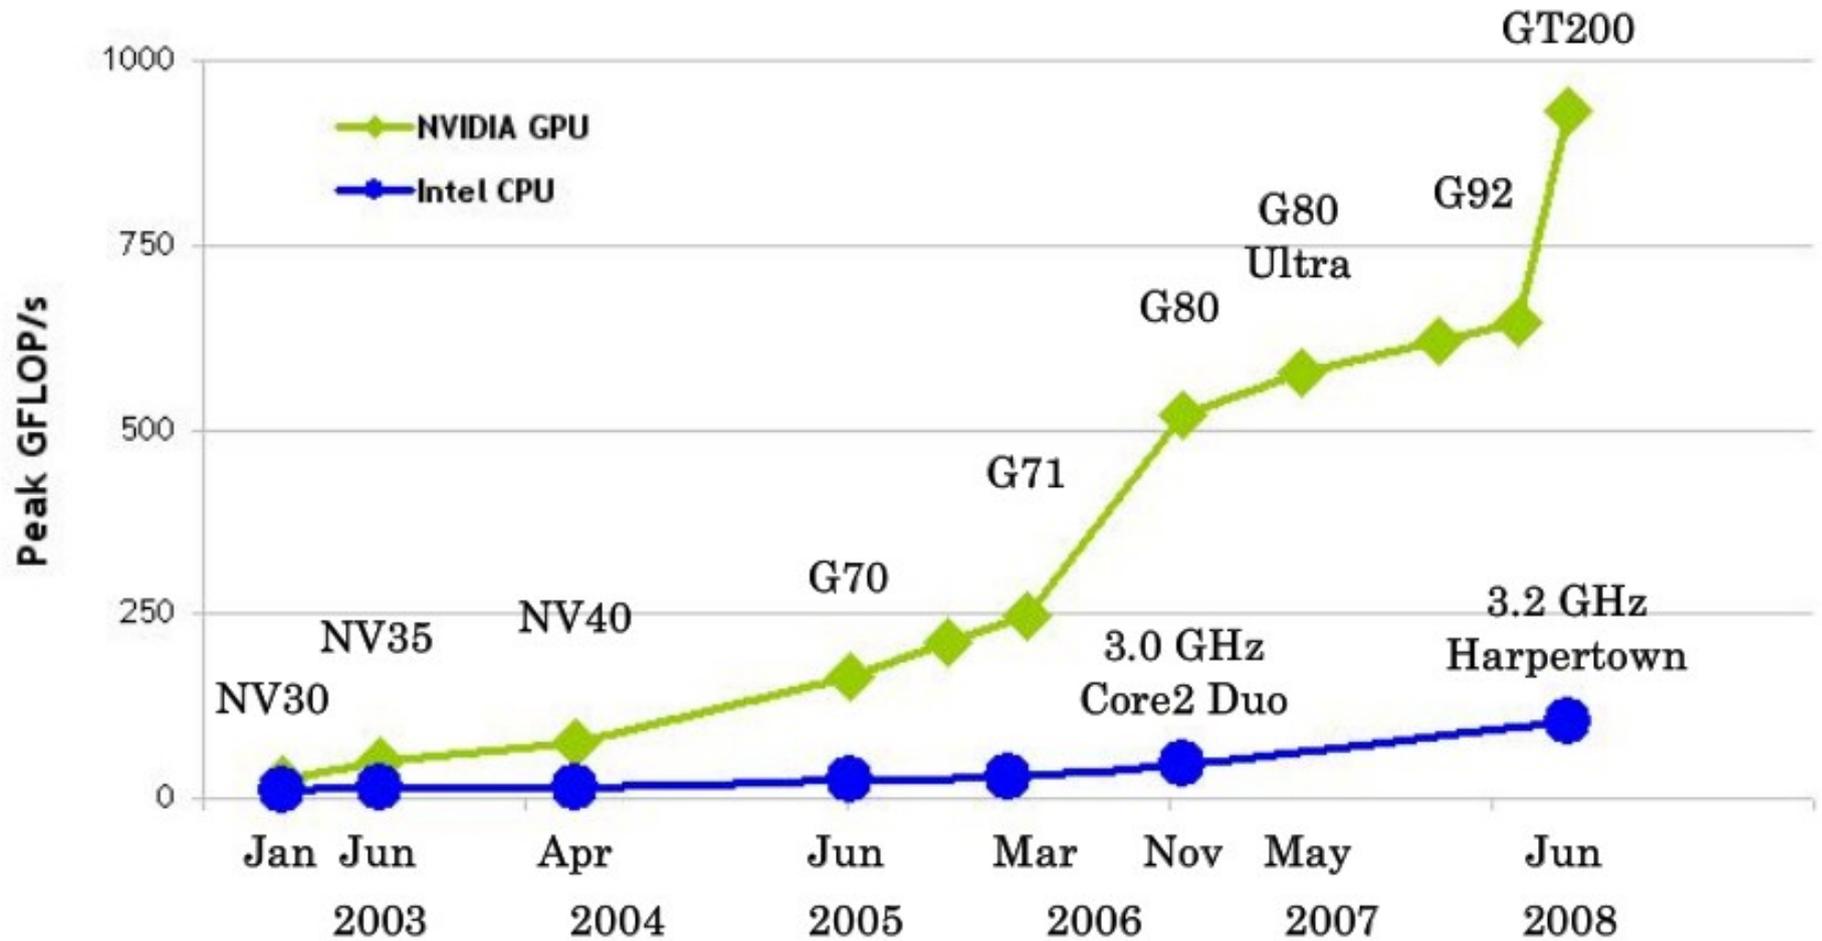
- Computation: 96 GFLOPS
- Memory bandwidth: 21GB/s
- Price: US\$ 570*
- Anual growth: 1.4x

NVidia GeForce 8800 GTX

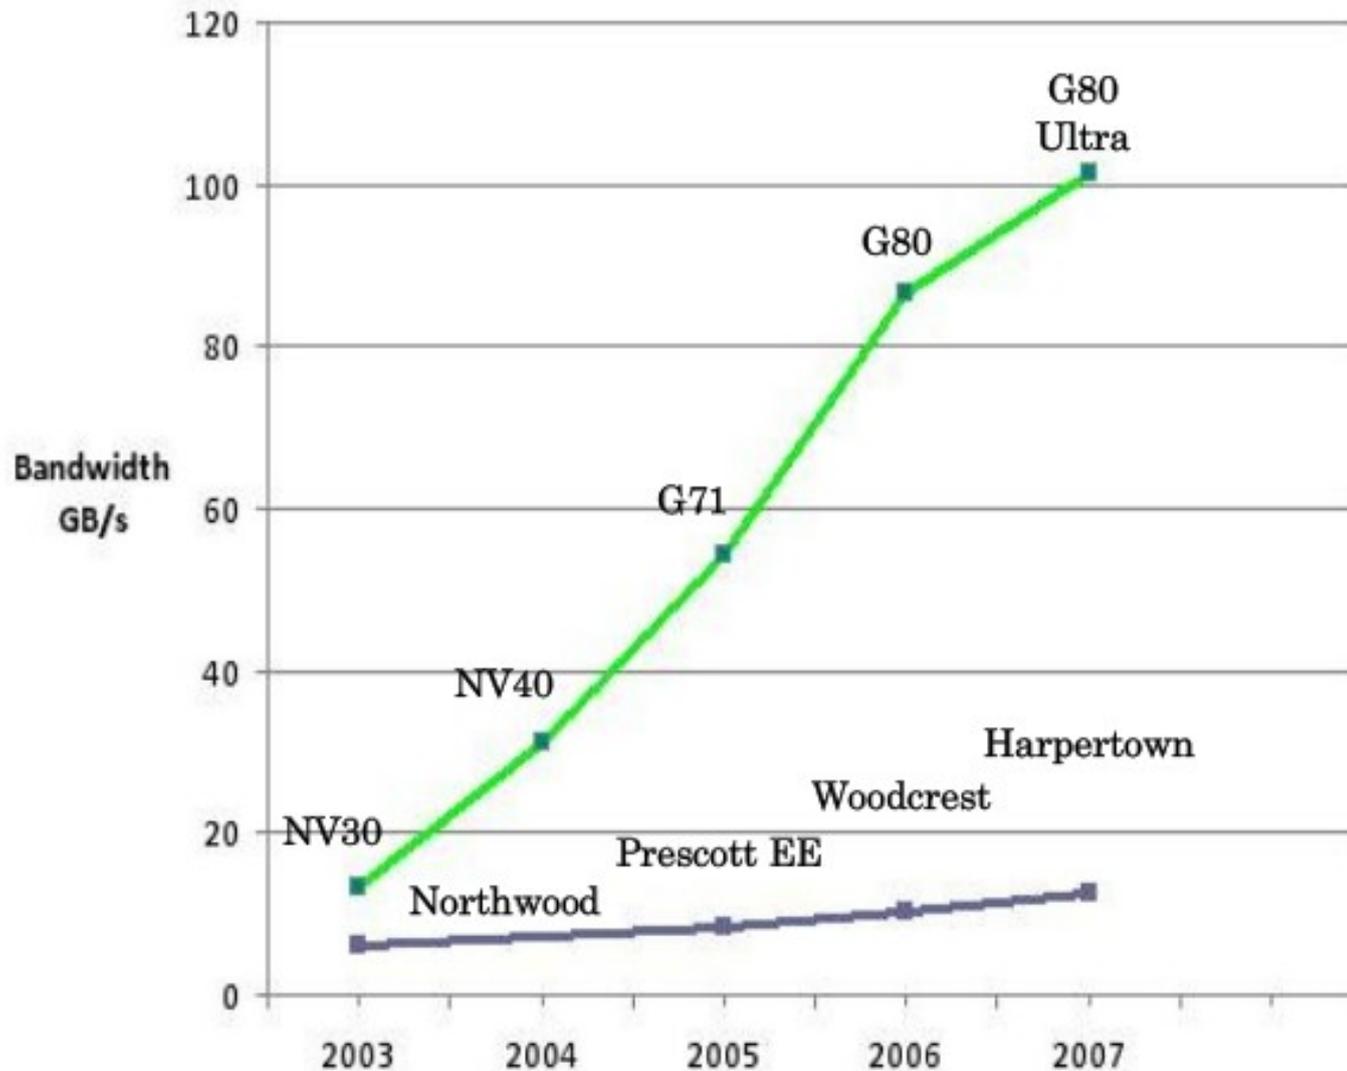
- Computation: 330 GFLOPS
- Memory bandwidth 86.4GB/s
- Price: \$300*
- 1.7x (fragment shader), 2.3x (vertex shader)

* Precios referidos al año 2008

GPU: poder de cómputo



GPU: ancho de banda



GPU: flexibilidad

- GPUs son altamente programables
 - Vertex shader, geometry shader y fragment shader
 - Lenguajes de programación de alto nivel

GPU: flexibilidad

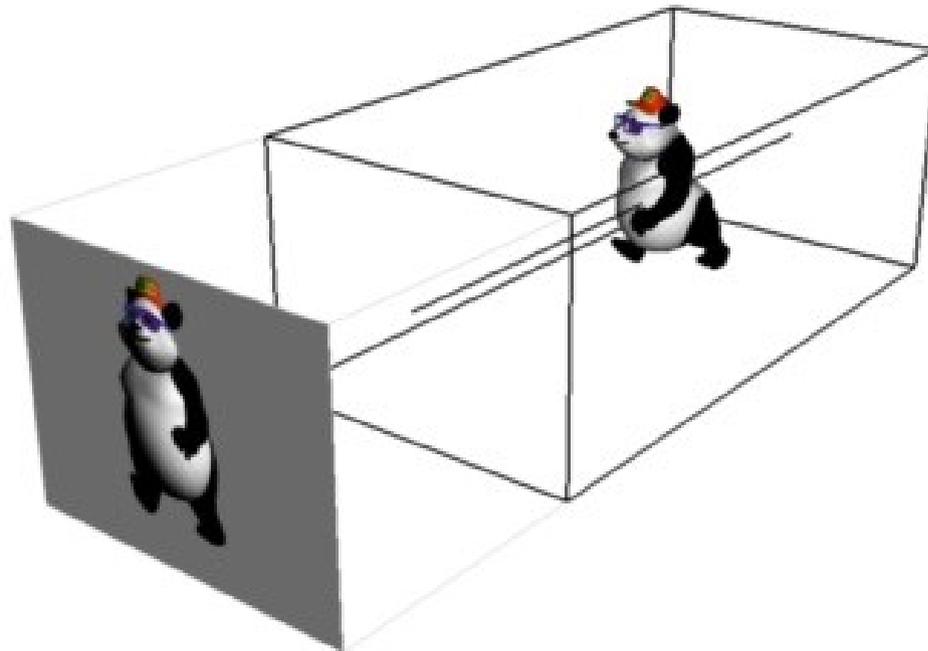
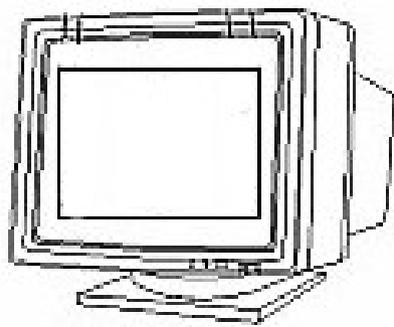
- GPUs son altamente programables
 - Vertex shader, geometry shader y fragment shader
 - Lenguajes de programación de alto nivel
- GPUs recientes soportan cálculos de alta precisión
 - 32 bits en todo el pipeline
 - Precisión suficiente para la mayoría de aplicaciones

GPU: flexibilidad

- GPUs son altamente programables
 - Vertex shader, geometry shader y fragment shader
 - Lenguajes de programación de alto nivel
- GPUs recientes soportan cálculos de alta precisión
 - 32 bits en todo el pipeline
 - Precisión suficiente para la mayoría de aplicaciones
- Tienen muchos núcleos y una arquitectura mas simple que una CPU estándar

¿Por qué son tan potentes?

- Originalmente diseñados para cálculo matemático y procesamiento paralelo intenso

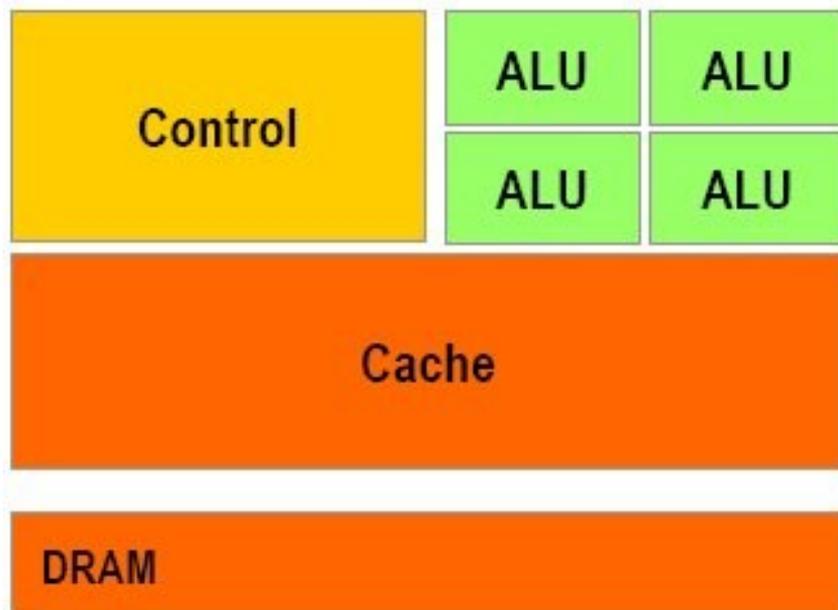


¿Por qué son tan potentes?

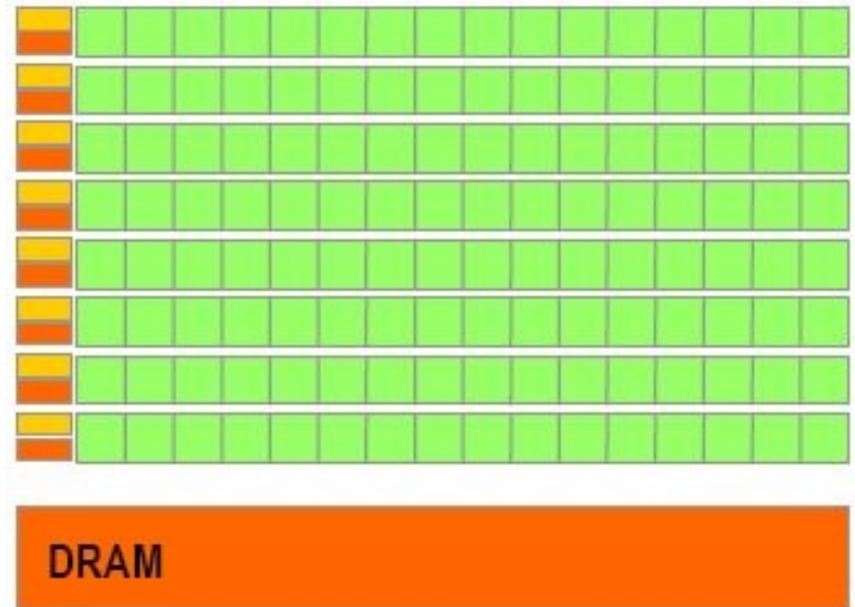
- Originalmente diseñados para cálculo matemático y procesamiento paralelo intenso
- Más transistores para procesamiento que para data caching y control de flujo

¿Por qué son tan potentes?

- Originalmente diseñados para cálculo matemático y procesamiento paralelo intenso
- Más transistores para procesamiento que para data caching y control de flujo



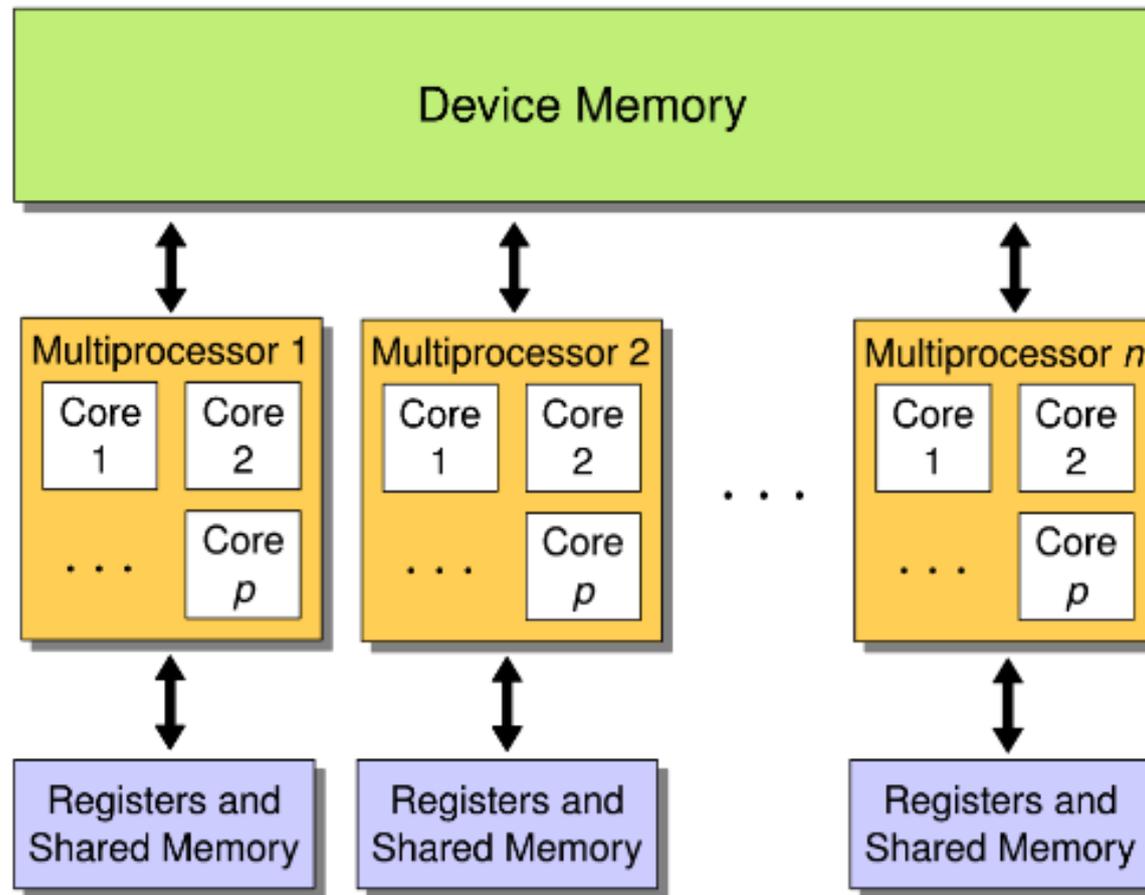
CPU



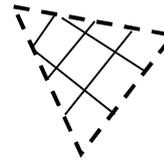
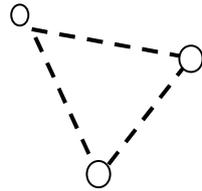
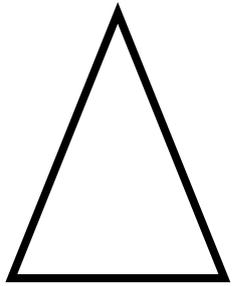
GPU

¿Por qué son tan potentes?

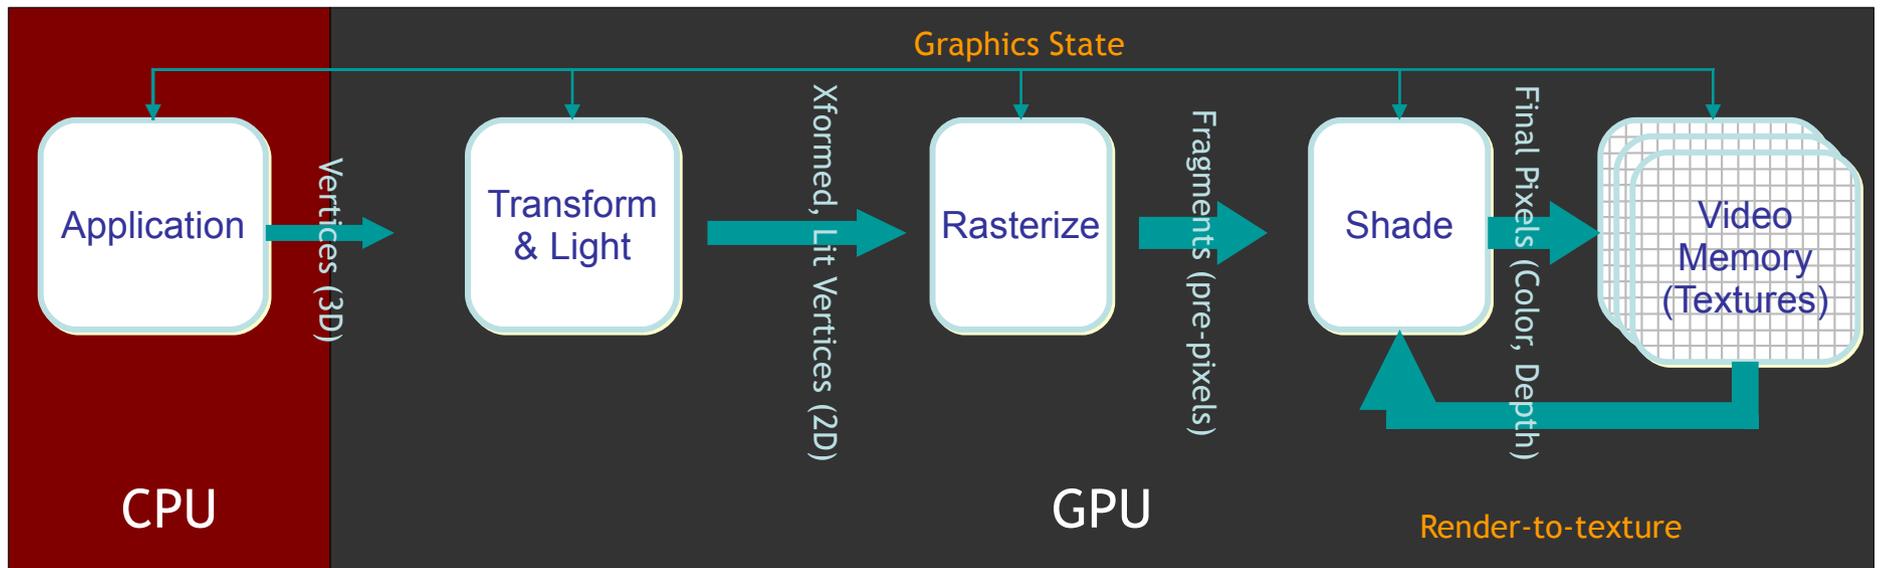
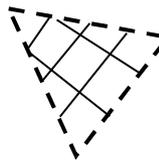
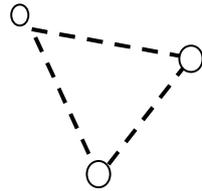
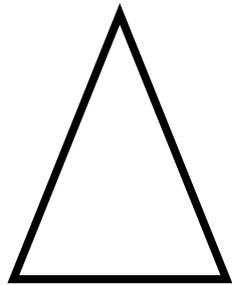
- Arquitectura simple



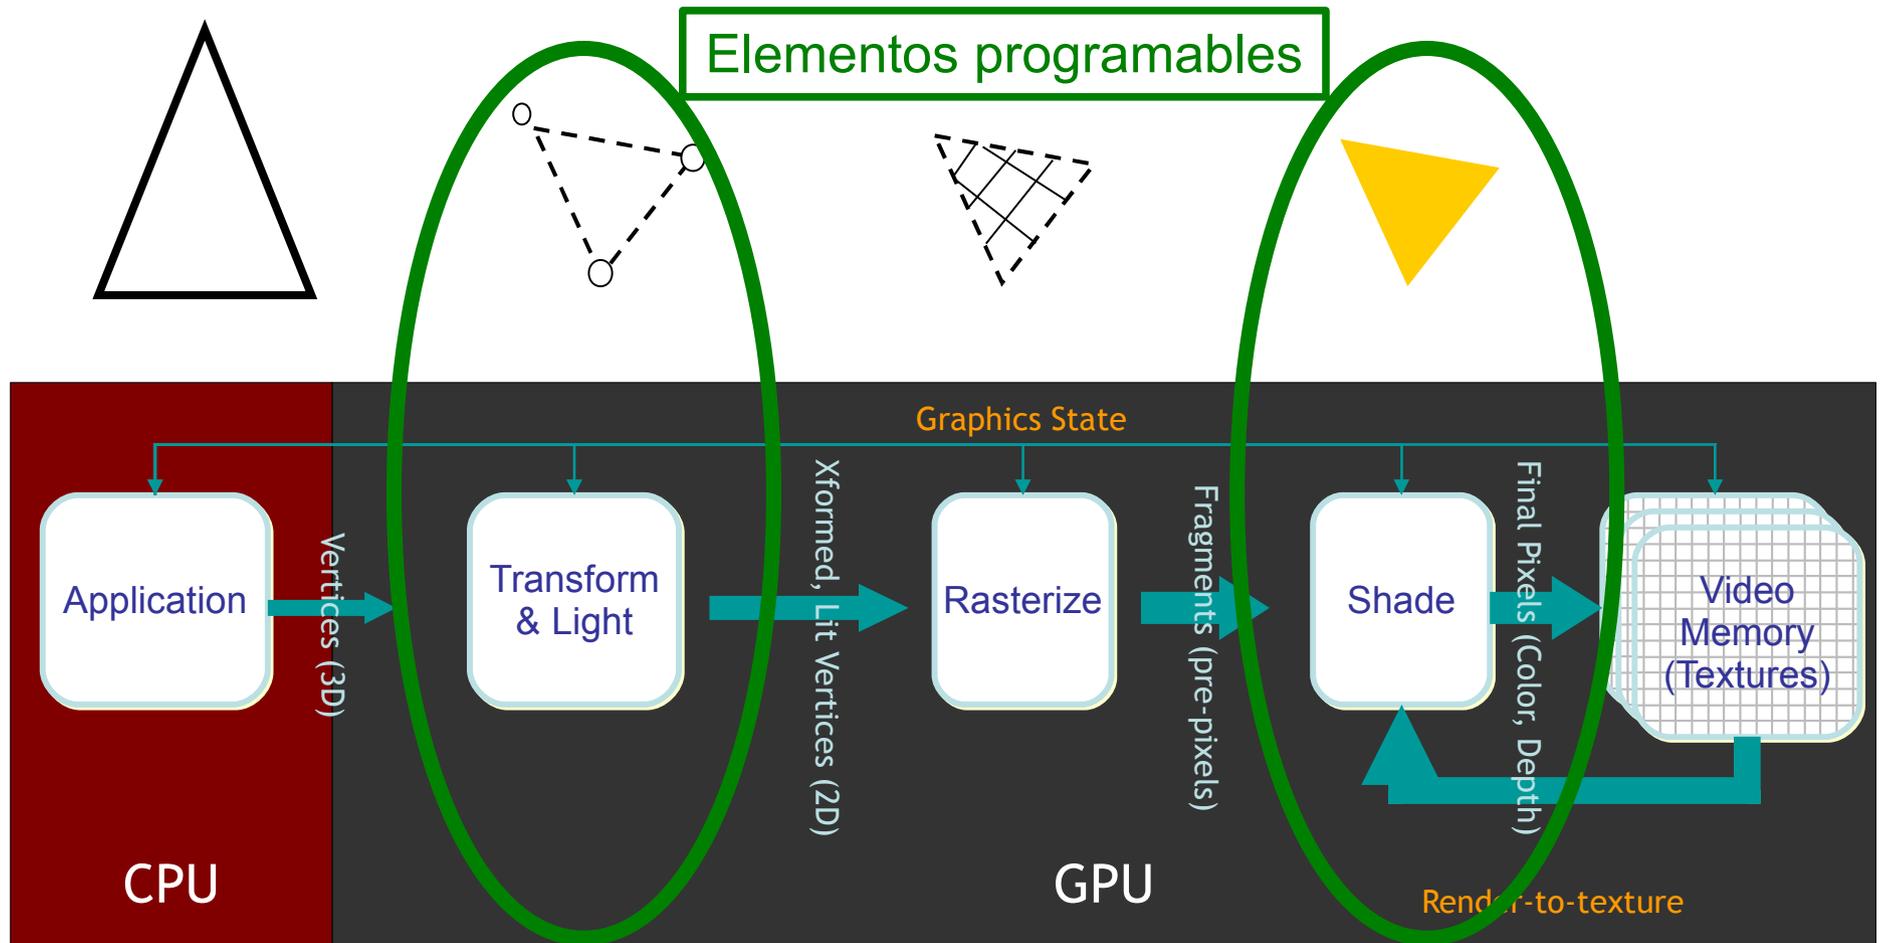
GPU: procesamiento gráfico




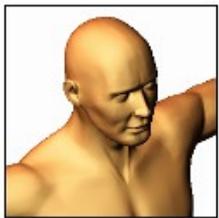
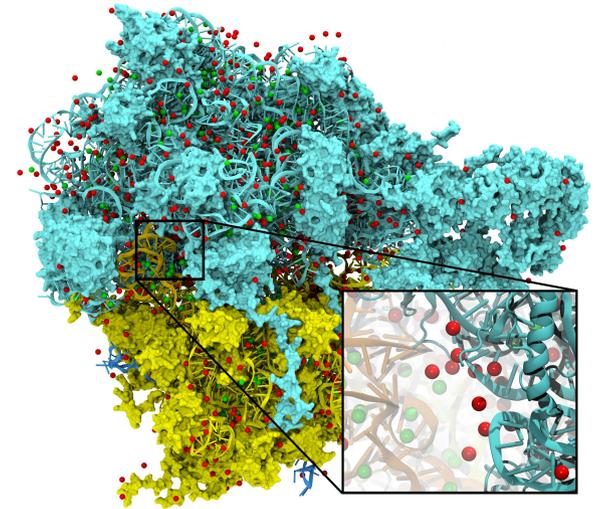
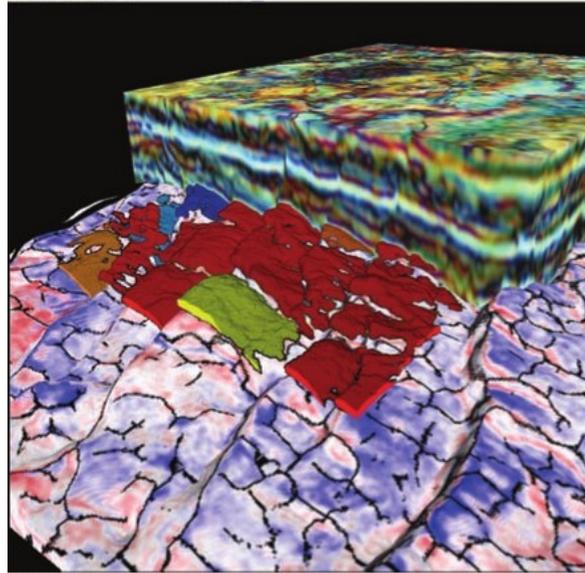
GPU: procesamiento gráfico



GPU: procesamiento gráfico



Aplicaciones recientes



Aplicaciones recientes



Aplicaciones recientes



Evolución de las GPUs

Pre-GPU	Soluciones costosas de S/H (SGI)	
1ra Gen	NVIDIA TNT2, ATI Rage, 3DFX Voodoo3	rasterization, no transformations
2da Gen	NVIDIA GeForce256 and GeForce 2, and the ATIRadeon 7500 (1999-2000)	transformation and lighting
3ra Gen	NVIDIA GeForce3 and GeForce4, and the ATI Radeon 8500 (2001-2002)	Vertex shader, limited instructions number, absence of program flow control, fixed-point numbers
4ta Gen	FX series and the ATI Radeon 9700 and 9800 (2003-2006)	Vertex and fragment shaders, texture data, floating-point numbers
5ta Gen	NVIDIA GeForce 8 series (2007-)	Graphics hardware for general-purpose computation

Programación de GPUs

- No es muy simple
- No se trata de "recompilar" código tradicional
- GPUs fueron diseñadas para procesamiento gráfico
 - Modelo de programación inusual
 - Programación dependiente del pipeline gráfico
 - Cg, GLSL
 - Ambiente de programación restringido
 - CTM(AMD), CUDA(NVIDIA), OpenCL, etc.

Programación de GPUs

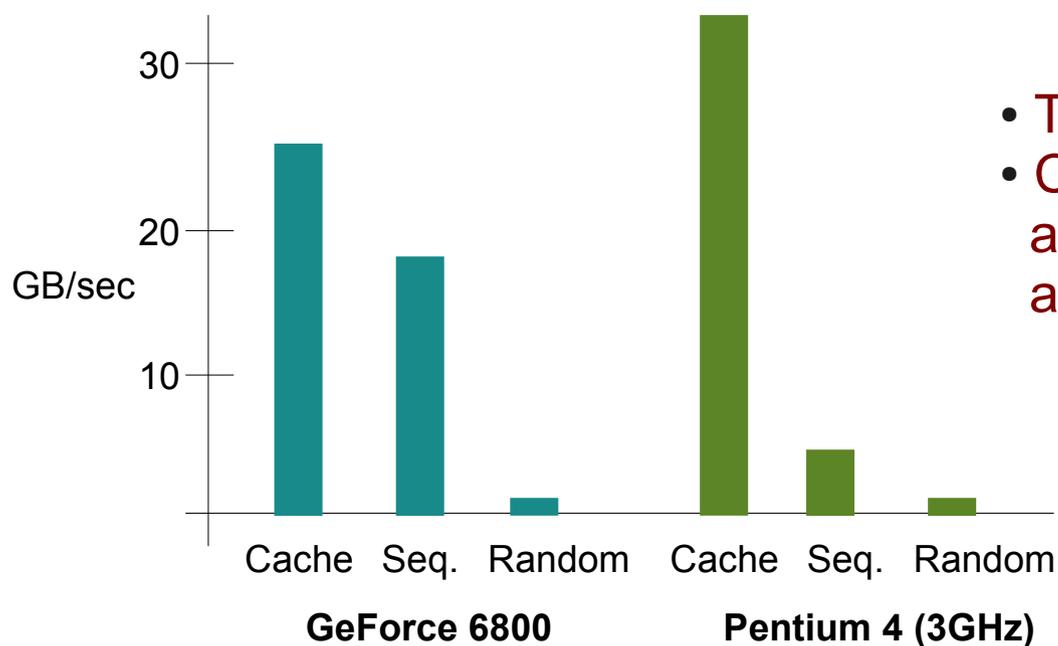
- Arquitecturas de GPUs
 - Ejecutan procesamiento paralelo
 - Evolución constante
 - Secreto del fabricante

Características de las GPUs

- Modelos de acceso a memoria
- Intensidad aritmética
- Transferencia de datos
- Operaciones típicas

Características de las GPUs

- Modelos de acceso a memoria
 - Cached, Sequential, Random



- Then ... locality, locality, locality
- Computation must be structured around sequential memory accesses

Comparación de desempeño de memoria: GPU vs. CPU

Características de las GPUs

- Intensidad aritmética
 - GPU fragment processor = 60 Gflops
 - Pentium4 = 12 Gflops
 - More computation! ... how much?
 - To cover memory latency our programs need to contain enough arithmetic instructions
 - $AI = \text{arithmetic_op} / \text{memory_op}$
 - Write algorithms with high AI !

Características de las GPUs

- Transferencia de datos entre la CPU y GPU
 - PCI: 3.2 GB/sec
 - Vector addition: $A+B = C$
 - How to avoid this penalty?
 - Amortize the data transfer cost

Características de las GPUs

- Operaciones típicas
 - Map
 - $M' = kM$, simple to implement on the GPU
 - Reduce
 - N to 1, multiple steps
 - Stream filtering
 - Non-uniform reduction, involves removing items
 - Sort/Search
 - Gatter(get) / Scatter(set)

Características de las GPUs

- Algoritmos paralelizables: aceleración $> \times 10$
 - Algoritmos que aplican la misma función a una gran cantidad de datos
 - Algoritmos que requieren cálculos de 32 bits
 - 64 bits es soportado
 - Algoritmos donde el monto de comunicación entre la CPU y la GPU es mínimo
- **No todo algoritmo es paralelizable!**